A network diagram consisting of various sized light blue circles connected by thin white lines, set against a solid blue background. The circles vary in size, with some being significantly larger than others, and they are interconnected in a complex, web-like structure.

Bedrijfstakonderzoek
BTO 2021.014 | Februari 2021

Het leidingnet in beeld

Bedrijfstakonderzoek

KWR

Rapport

Het leidingnet in beeld

BTO 2021.014 | Februari 2021

Dit onderzoek is onderdeel van het collectieve Bedrijfstakonderzoek van KWR, de waterbedrijven en Vewin.

Opdrachtnummer

402045/210

Projectmanager

Geertje Pronk

Opdrachtgever

BTO - Thematisch onderzoek - Hydroinformatica

Auteur(s)

dr. ir. K.A. (Karel) van Laarhoven, dr. X. (Xin) Tian

Kwaliteitsborger(s)

dr. P. (Peter) van Thienen

Verzonden naar

Dit rapport is verspreid onder BTO-participanten.

Een jaar na publicatie is het openbaar.

Keywords

leidinginspectie, beeldverwerking, objectherkenning

Jaar van publicatie

2021

Meer informatie

Karel van Laarhoven

T +31 30 606 9697

E Karel.van.Laarhoven@kwrwater.nl

PO Box 1072

3430 BB Nieuwegein

The Netherlands

T +31 (0)30 60 69 511

F +31 (0)30 60 61 165

E info@kwrwater.nl

I www.kwrwater.nl

KWR

Februari 2021 ©


Alle rechten voorbehouden aan KWR. Niets uit deze uitgave mag - zonder voorafgaande schriftelijke toestemming van KWR - worden verveelvoudigd, opgeslagen in een geautomatiseerd gegevensbestand, of openbaar gemaakt, in enige vorm of op enige wijze, hetzij elektronisch, mechanisch, door fotokopieën, opnamen, of enig andere manier.

Managementsamenvatting

Het leidingnet in beeld

Auteur(s) Karel van Laarhoven, Xin Tian

Om een beter beeld te krijgen van onze ondergrondse drinkwaterleidingen, worden er steeds meer inspecties op afstand uitgevoerd. Dit betekent dat er ook steeds meer data beschikbaar komt en dat het steeds meer werk wordt om die data te verwerken en te duiden. In dit onderzoek illustreren we hoe automatische verwerking van één specifieke vorm van data, videobeelden, de drinkwaterbedrijven al goed van dienst kan zijn. Door videobeelden te vertalen naar leidingeigenschappen zoals de locatie van aansluitingen en verbindingen, brengen we letterlijk het leidingnet in beeld.



Voorbeeld van een verbinding die automatisch wordt gedetecteerd in bestaande inspectiedata van WML met het demonstratiealgoritme.

Belang: van inspectiedata naar *digital twin*

Het ondergrondse drinkwaterleidingnet is lang een zwarte doos geweest. Nog steeds is ons beeld van de toestand van de leidingen beperkt en grotendeels gebaseerd op inschattingen. Dit geldt bijvoorbeeld zelfs voor de exacte ligging van leidingen. Omdat waterbedrijven steeds meer van op ervaring gebaseerde beslissingen naar op informatie gebaseerde beslissingen overgaan, wordt het cruciaal dat deze informatiebasis correct is. Om aan die behoefte te voldoen, wordt er steeds meer data verzameld met allerlei inspecties. Naarmate de

hoeveelheid data groeit, wordt het echter steeds meer werk om die data ook goed te verwerken en interpreteren. Deze interpretatiestap is essentieel voor de constructie van een digitaal evenbeeld van het leidingnet waarop de toekomstige drinkwaterexpert zijn of haar beslissingen op kan baseren.

Aanpak: onderzoek de mogelijkheden van automatische interpretatie van inspectiedata

In dit onderzoek illustreren we hoe automatische verwerking van data de drinkwaterexpert van dienst

kan zijn. We richten ons hierbij op één specifieke soort data: videobeelden. In sommige gevallen zal het interpreteren van videobeelden te complex zijn om handmatig uit te voeren, maar in nog veel meer gevallen zal handmatige interpretatie simpelweg te tijdrovend zijn. Mensen zijn bijvoorbeeld typisch goed in staat om (te leren om) videobeelden in één oogopslag te duiden en daar de belangrijke zaken in te identificeren, maar het is zeer arbeidsintensief werk om duizenden uren beeldmateriaal handmatig door te werken en daar alle belangrijke zaken uit op te tekenen voor verdere verwerking.

Zou dit dan niet een perfecte klus voor de computer zijn? Via een literatuurstudie is onderzocht wat de mogelijkheden van beeldherkenning voor leidinginspecties zijn. Vervolgens proberen we enkele veelbelovende technieken uit op videobeelden van het leidingnet die door drinkwaterbedrijven eerder zijn verzameld, ter illustratie.

Resultaten: tal van beeldherkenningstechnieken kunnen de drinkwaterbedrijven helpen

Uit de literatuurstudie blijkt dat beeldherkenning een voldoende breed ontwikkeld veld is om bijna direct toe te passen op drinkwaterinspecties. Er kan veel geleerd worden van de afvalwaterwereld, waar videoinspecties en hun geautomatiseerde verwerking al langer op de agenda staan.

De historische inspectiedata die de drinkwaterbedrijven beschikbaar hadden bleek erg divers wat betreft kwaliteit en opnametechniek. Toch kon met conventionele beeldherkenningstechnieken relatief eenvoudig een algoritme worden opgesteld om verbindingen te detecteren in alle verschillende video's. Dit laat zien dat je met conventionele technieken al ver komt. De zogenaamde *machine-learning* technieken zullen in de toekomst voor nog een extra verbeterslag zorgen, maar de huidige beschikbare hoeveelheid data is nog niet toereikend om dergelijke algoritmen op te zetten.

Toepassing: voorsorteren op automatisering via het uniformiseren van inspecties

Aangezien de drinkwatersector nog maar aan het begin staat van grootschalige in-line inspectie van het leidingnet, zijn er nu kansen om goed rekening te houden met de automatische verwerking van alle data die in de toekomst zal worden verzameld.

Door samen af te stemmen over de manier waarop data verzameld en opgeslagen wordt, kunnen drinkwaterbedrijven zorgen voor een efficiënte kennisopbouw. Door data ieder op dezelfde manier te verzamelen kan de eerste 'golf' van data gemakkelijk samen worden opgebouwd en vervolgens worden verkend met gezamenlijke analyses op basis van conventionele beeldverwerkingstechnieken. Op die manier wordt een goed beeld verkregen van alle verschillende situaties die in het leidingnet kunnen voorkomen en dus geïdentificeerd moeten kunnen worden uit de data.

De drinkwaterbedrijven kunnen dan vervolgens ook afstemmen over de classificatie van verschillende te identificeren situaties. Door allemaal op vergelijkbare wijze data te blijven verzamelen en deze op vergelijkbare wijze te analyseren kan data zo snel mogelijk worden gebundeld om de stap te maken naar automatische verwerking met behulp van de robuustere *machine-learning* technieken. De beschikbaarheid van uniforme inspectiebeelden zal deze stap maken of breken.

Naast de automatische verwerking van data naar leidingeigenschappen is het vervolgens ook van belang om aandacht te blijven houden voor modelmatige vertaling van dergelijke eigenschappen naar abstractere informatie zoals 'conditie' of 'risico op klachten', zodat uiteindelijk de stap van data naar beslissing volledig kan worden ondersteund.

Het Rapport

Dit onderzoek is beschreven in het rapport *Het Leidingnet in Beeld* (BTO 2021.014).

Inhoud

<i>Managementsamenvatting</i>	2
Inhoud4	
1 Inleiding	5
1.1 Motivatie en doel	5
1.2 Aanpak en leeswijzer	6
2 Inspiratie voor beeldherkenning bij leidinginspecties	7
2.1 Beeldverwerking en beeldherkenning	7
2.2 Toepassingen in afvalwater	9
2.3 Bouwstenen voor beeldherkenningsalgoritmen	11
2.4 Usecases voor drinkwaterbedrijven	13
3 Beeldherkenning toegepast op bestaande inspectiedata	15
3.1 Case study data	15
3.1.1 Evides	15
3.1.2 Vitens	15
3.1.3 WML	16
3.2 Keuze voor een specifieke aanpak	17
3.3 Beeldherkenningsalgoritme voor verbindingen	17
3.3.1 Beelden inlezen en voorbereiden	18
3.3.2 Segmentatie	19
3.3.3 Dilatatie	20
3.3.4 Extractie van kenmerken met de Cirkel Houghtransformatie	21
3.4 Het herkennen van aansluitleidingen	24
4 Naar de toepassing van beeldherkenning voor automatische interpretatie van inspecties	25
4.1 Discussie	25
4.2 Conclusies	27
4.3 Roadmap/aanbevelingen voor drinkwaterbedrijven om te komen tot automatische interpretatie van visuele inspecties	28
4.4 Aanbeveling voor gerelateerd onderzoek	29
5 Literatuur	30

1 Inleiding


1.1 Motivatie en doel

Het ondergrondse drinkwaterleidingnet is lang een zwarte doos geweest. Nog steeds is ons beeld van de toestand van de leidingen beperkt en grotendeels gebaseerd op inschattingen. Dit geldt eveneens voor de exacte ligging van leidingen en in beperktere mate ook voor de connectiviteit. Omdat waterbedrijven steeds meer van op ervaring gebaseerde beslissingen naar op informatie gebaseerde beslissingen overgaan, wordt het cruciaal dat deze informatiebasis correct is. Zo moet iemand die een beslissing baseert op de uitkomst van een hydraulische berekening kunnen vertrouwen op de invoergegevens van het hydraulische model, zoals de exacte topologie en connectiviteit, maar ook zaken zoals materialen, diameters en afsluiterstanden.

De afgelopen decennia zijn er diverse inspectietools ontwikkeld die stukjes van deze zwarte doos hebben geopend voor de drinkwaterbedrijven, zoals de Aquarius en de Air in-line inspectie platforms. Van individuele leidingen komt hierdoor meer data beschikbaar. Binnen het komende decennium kunnen door de introductie van inspectierobots en nieuwe sensoriek enorme hoeveelheden data over de begraven infrastructuur beschikbaar komen. Dit biedt de kans om de zwarte doos volledig te openen, oftewel om een volledig en actueel beeld van het begraven leidingnet te hebben wat betreft toestand, topologie, verschillende componenten etc.

Het beschikbaar komen van al die nieuwe data brengt ook nieuwe uitdagingen met zich mee. Eén daarvan zal zijn om deze grote hoeveelheid data te interpreteren: om videobeelden, radar- en geluidssignalen, gps-coördinaten en andere meetgegevens te vertalen naar afsluiterstanden, wanddiktes, materialen, diameters, locaties van buizen, verbindingen of appendages en dergelijken. Deze interpretatiestap is essentieel voor de constructie van een digitaal evenbeeld van het leidingnet waarop de toekomstige drinkwaterexpert zijn of haar beslissingen op kan baseren. In sommige gevallen zal deze stap te complex zijn om handmatig uit te voeren, maar in nog veel meer gevallen zal handmatige interpretatie simpelweg te tijdrovend zijn. Mensen zijn bijvoorbeeld typisch goed in staat om (te leren om) videobeelden in één oogopslag te duiden en daar de belangrijke zaken in te identificeren, maar het is zeer arbeidsintensief werk om duizenden uren beeldmateriaal handmatig door te werken en daar alle belangrijke zaken uit op te tekenen voor verdere verwerking.

In het voorliggende rapport gaan we dieper in op het voorbeeld van die videobeelden uit inspecties. Het doel is om een proof-of-concept te geven van automatische interpretatie van visuele data afkomstig van inspectietools en -robots. Op die manier wordt gedemonstreerd dat hiermee een significante verbetering van kennis van het leidingnet en van de kwaliteit van de beschikbare data hiervan valt te realiseren. Figuur 1 illustreert hoe dit past in de keten van data naar assetmanagementbeslissingen en -beleid.



Figuur 1. In de keten van datavergaring naar assetmanagementbeslissingen en -beleid richt dit project zich op de schakel van processing/interpretatie van data. Er vindt terugkoppeling naar voorafgaande schakels plaats.

1.2 Aanpak en leeswijzer

Dit onderzoek begint met een korte literatuurstudie waarin wordt gekeken naar de stand van de techniek van automatische beeldherkenning, relevante toepassingen in andere sectoren en de verschillende aanpakken die hierbij typisch worden gebruikt. Op basis daarvan bespreken we in welke usecases deze technieken een meerwaarde kunnen hebben bij inspecties van drinkwaterleidingen. Dit wordt beschreven in hoofdstuk 2.

Vervolgens wordt voorbeelddata verzameld van bestaande inspecties. Op basis van de bevindingen uit de literatuurstudie en de aard van de voorbeelddata wordt een aanpak voor een beeldherkenningsalgoritme gekozen en uitgewerkt, om beeldherkenning bij inspecties van waterleidingen te illustreren. Dit wordt beschreven in hoofdstuk 3.

De lessen uit de voorgaande hoofdstukken worden bediscussieerd in hoofdstuk 4. Er wordt besproken welke stappen er nodig zijn om geautomatiseerde, visuele leidinginspecties makkelijker en krachtiger te maken met behulp van beeldherkenningstechnieken. Vervolgens worden de conclusies en aanbevelingen voor de drinkwaterbedrijven die volgen uit dit werk samengevat.


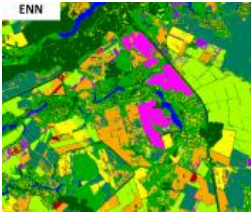

2 Inspiratie voor beeldherkenning bij leidinginspecties

2.1 Beeldverwerking en beeldherkenning

Videobeelden bieden ons een duidelijke en intuïtieve vorm van data om waar te nemen en vast te leggen wat er in onze systemen gebeurt. Digitale beeldverwerking omvat een breed veld van algoritmen die beelden gebruiken als initiële invoer. Het veld is ontstaan in de jaren zestig, met als oorspronkelijke doel het verbeteren van de kwaliteit van beelden, bijvoorbeeld door het filteren van ruis en het vergroten van contrast. Inmiddels zijn er echter ook tal van algoritmen ontwikkeld die niet zozeer gericht zijn op het aanpassen van beelden, maar op het extraheren van bepaalde informatie die in beelden aanwezig is. Als het hierbij gaat om het herkennen en omschrijven van objecten die in de beelden 'te zien zijn', spreekt men ook van de velden beeldherkenning en *computer vision*. Automatische beeldherkenning heeft reeds in vele sectoren toepassing gevonden, zoals het interpreteren van satellietbeelden, het ondersteunen van diagnoses op basis van medische beeldvorming of het aansturen van zelfrijdende voertuigen.

Beeldwerking en beeldherkenning maken nog steeds een sterke ontwikkeling door dankzij het beschikbaar komen van steeds krachtigere hardware en steeds verder verfijnde algoritmen (zeker sinds de opkomst van machine learning). Op verschillende technische gebieden wordt beeldherkenning op grote schaal gebruikt om experts te helpen bij een aantal taken die op elkaar voortbouwen: het **detecteren** van afwijkingen of objecten, het **classificeren** van verschillende gedetecteerde objecten, en het **herkennen** van patronen daarin. In Tabel 1 staan drie voorbeelden van de toepassing van deze beeldherkenningstaken.

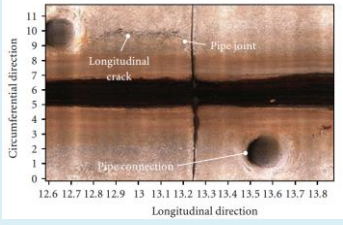
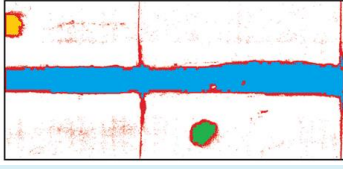
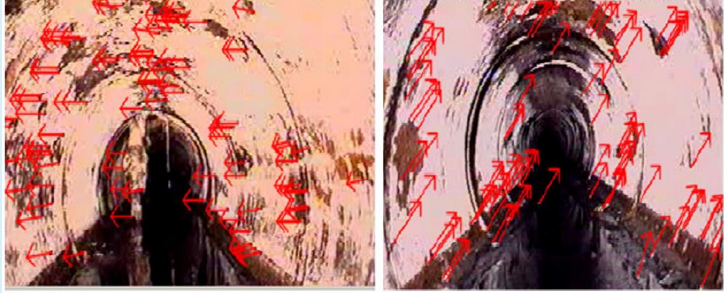
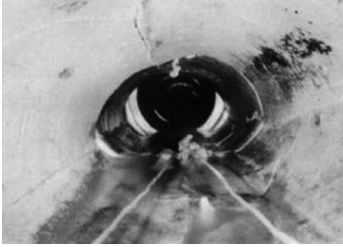
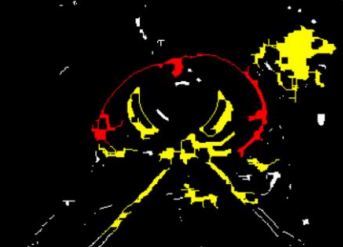

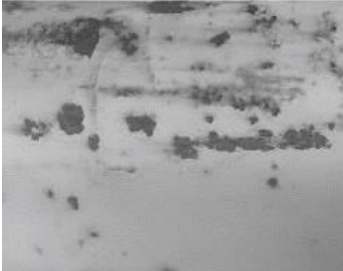

Tabel 1. Drie verschillende computer vision taken, toegepast in usecases uit drie verschillende sectoren.

Domein - Discipline	Voorbeeld		Belang voor drinkwaterleidingen
Civiele techniek - Conditiebepaling	Detectie en/of metrologie (kwantificeren) van afwijkingen, zoals in dit geval scheuren of imperfecties in een verder egaal oppervlak (Hoang, 2018).		Het detecteren en kwantificeren van schade en afwijkingen, maar bijvoorbeeld ook het detecteren van verbindingen, appendages, aansluitingen, aftakkingen.
Landbouw - Teledetectie	Classificatie (sorteren) van verschillende objecten die in een bepaalde beeld gedetecteerd zijn, zoals landgebruik op basis van satellietbeelden (Kussul et al., 2017).		Noodzakelijk om de verschillende gedetecteerde objecten uit elkaar te houden. Bijvoorbeeld ook om twee typen verbindingen van elkaar te onderscheiden.
Vekeer - Beeldherkenning	Herkenning van patronen in de gedetecteerde en geclassificeerde objecten, bijvoorbeeld het volgen van een bepaald object over opeenvolgende videobeelden, zoals een auto of een voetganger (Zhang et al., 2017).		Waarschijnlijk niet direct van belang om meer over leidingen te weten te komen, maar bijvoorbeeld wel om de navigatie van inspectietools door het leidingnet te ondersteunen.



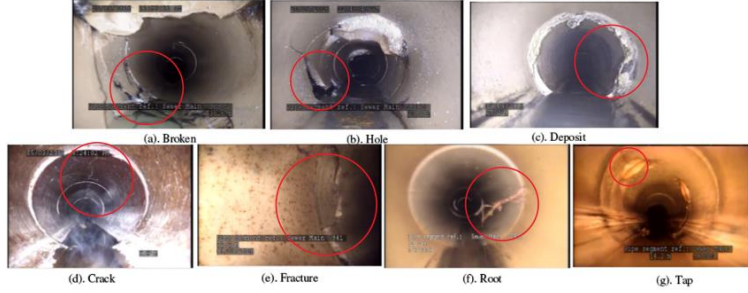
2.2 Toepassingen in afvalwater

Tabel 1 geeft reeds een beperkt beeld van de diversiteit in toepassingsmogelijkheden van beeldherkenning in verschillende sectoren. Koch et al. (2015) geven een uitgebreid overzicht van de toepassing van beeldherkenning bij conditie-inspecties van verschillende typen civiele infrastructuur, zoals bruggen, tunnels, leidingen en wegen. Interessant genoeg blijkt met name de automatische inspectie van afvalwaterleidingen reeds een ver ontwikkeld veld. Koch en collega's stellen dat dit – net als in de drinkwatersector – is omdat alternatieve vormen van inspectie bemoeilijkt worden door de beperkte bereikbaarheid van de leidingen, terwijl inspecties wel degelijk gewenst zijn vanwege de hoge kosten die gemoeid zijn met onderhoud en reparaties. Een recent en uitgebreide overzicht van de stand van de techniek in beeldherkenning voor afvalwater wordt gegeven door Haurum en Moeslund (2020). Ook in Nederland is beeldherkenning in het afvalwaternetwerk onderwerp van onderzoek, bijvoorbeeld in het recente SewerSense-programma aan de Universiteit Delft. Het is daarbij goed om op te merken dat het bestaan voorstandaarden voor de manier van het verzamelen van inspectiebeelden wereldwijd heeft geleid tot een grote dataset van vergelijkbare beelden die geschikt is voor automatische verwerking. Aangezien dergelijke inspecties ook in leidingen worden uitgevoerd (met uiteraard het verschil met drinkwater dat de leiding niet volledig onder water staat), bieden deze studies ons goede referenties voor de mogelijkheden van automatische inspectie van drinkwatersystemen. Enkele veelbelovende toepassingen van beeldverwerking in afvalwaternetwerken uit verschillende studies zijn samengevat in Tabel 2.

Tabel 2. Voorbeelden van beeldherkenning bij geautomatiseerde afvalwaterleidinginspecties.

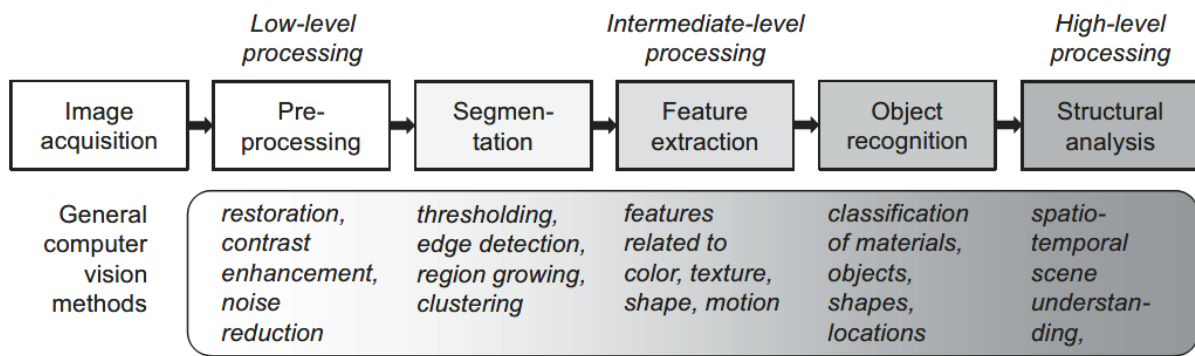
Samenvatting en inspiratie	Voorbeeld van invoerdata	Voorbeeld van verwerkte data
<p>Detectie van onderdelen en defecten (Mashford et al., 2009)</p> <p>In deze vroege studie van beeldherkenning in afvalwater worden verschillende componenten en defecten gedetecteerd met conventionele selectie op basis van drempelwaarden. Ook in drinkwatersystemen zal het waardevol zijn om dergelijke zaken in kaart te brengen.</p>		
<p>Corrigeren van de eigen positie op basis van patroonherkenning (Mahmoud et al., 2014)</p> <p>Uit het patroon in de bewegingen van verschillende kenmerken over verschillende beelden heen wordt de precieze beweging van de camera geconstrueerd. Hiermee wordt vervolgens het inmeten van de inspectie in het leidingnet verbeterd.</p>		
<p>Detectie van defecten (Su et al., 2011)</p> <p>In deze studie is beeldverwerking toegepast om buisdefecten (b.v. vervorming zoals in rood op de foto) van rioolstelsels op te sporen. Het zou waardevol kunnen zijn om soortgelijke problemen ook in kaart te brengen voor drinkwatersystemen.</p>		
<p>Detectie van stroomlijnen (Kirstein et al., 2012)</p> <p>In deze studie is beeldverwerking toegepast om de waterspiegel in afvalwaterleidingen te bepalen. Hoewel dit niet direct van belang is in drinkwatersystemen, zouden er wel andere structuren in lengterichting interessant kunnen zijn om te meten, zoals sediment.</p>		
<p>Detectie van corrosie (Bondada et al., 2018)</p> <p>In deze studie wordt kleuranalyse gebruik om aantasting (roest) van vuil te onderscheiden in foto's van buiswanden gemaakt met mobiele telefoons. Ook in drinkwatersystemen zal detectie van objecten bemoeilijkt worden door de aanwezigheid van biofilm en andere verkleuring.</p>		

Tabel 2, voortgezet. Voorbeelden van beeldherkenning bij geautomatiseerde afvalwaterleidinginspecties.

Samenvatting en inspiratie	Voorbeeld van invoerdata	Voorbeeld van verwerkte data
<p>Labelen van objecten (Kunzel et al., 2018)</p> <p>Een moderne variant van de eerste studie in deze tabel. Moderne <i>machine-learning</i> technieken worden gebruikt om een veelvoud van verschillende objecten te identificeren en labelen in inspectiebeelden. Ook voor drinkwatersystemen zou een dergelijke oplossing een krachtig middel zijn.</p>		
<p>Automatische detectie van bijzonderheden (Yin et al., 2019)</p> <p>Moderne <i>machine-learning</i> technieken worden gebruikt om een eerste schifting in inspectiebeelden te maken. Zaken die de aandacht van de expert verdienen worden naar voren gebracht. Zodra er grote hoeveelheden beelden beschikbaar komen voor drinkwatersystemen, zal een dergelijke techniek een krachtig middel zijn voor interpretatie en ook voor het trainen van beeldherkenningsalgoritmen (bij dergelijke training zal de expert in eerste instantie alle bijzonderheden aan de computer moeten aanwijzen).</p>		

2.3 Bouwstenen voor beeldherkenningsalgoritmen

Figuur 2 toont in de rechthoekige blokken de stappen die achtereenvolgens worden gezet bij conventionele beeldherkenning. Wanneer men over beeldherkenning denkt, is het goed om te beginnen bij het verwerven van de beelden (**image acquisition**), want de gebruikte meettechniek en bijvoorbeeld belichtingsomstandigheden kunnen grote invloed hebben op de opvolgende stappen. Een overzicht van technieken die doorgaans worden gebruikt voor de visuele inspectie van pijpleidingen wordt besproken door Liu en Kleiner (2012). Na het verwerven van beelden moeten deze vaak worden voorbereid (**pre-processing**) om opvolgende stappen makkelijker te maken. Daarbij kan men denken aan zaken zoals het filteren van ruis, het vergroten van contrast of het aanpassen van kleuren. Vervolgens wordt het beeld opgedeeld in regio's – segmenten – die op de een of andere manier van elkaar verschillen (**segmentation**), bijvoorbeeld op basis van scherpe overgangen in kleur of intensiteit. Vervolgens worden de segmenten abstract samengevat in termen van kenmerken zoals vormen, diameters en kleuren (**feature extraction**). Deze kenmerken zijn de fundamentele informatie op basis waarvan het algoritme verschillende objecten vervolgens kan herkennen, onderscheiden en classificeren (**object recognition**). Ten slotte moet de nuttige informatie die uit één beeld of een reeks beelden wordt gehaald, worden samengevat en vertaald in een interpreteerbare boodschap, op basis waarvan de systeemoperator gemakkelijk de toestand van het systeem kan begrijpen en/of beslissingen kan nemen (**structural analysis**). Onder de vierkante blokken in Figuur 2 zijn omschrijvingen van deelalgoritmen die veel in deze stappen worden gebruikt opgesomd. Een breed overzicht van verschillende conventionele algoritmen voor beeldherkenning en hun beschrijving is bijvoorbeeld ook te vinden in (Parker, 2010).



Figuur 2. Boven: de algemene stappen bij automatische beeldherkenning (vierkante blokken) en voorbeelden van veelgebruikte algemene technieken om die stappen te bewerkstelligen (het afgeronde kader). Overgenomen uit Koch et al. (2015).

Als we de bovenstaande stappen van conventionele beeldherkenning doorlopen, proberen we als het ware stapsgewijs en expliciet de te detecteren objecten te omschrijven in ‘woorden die de computer begrijpt’. Deze stapsgewijze opbouw wordt aan de hand van een drinkwatervoorbeeld geïllustreerd in sectie 3.3 in het volgende hoofdstuk. Naast de conventionele methoden voor beeldherkenning zijn inmiddels ook moderne *machine-learning* technieken voor beeldherkenning sterk in opkomst. Met name de toepassing *deep learning* door kunstmatige neurale netwerken wordt gezien als een doorbraak voor beeldherkenning. Deze familie van algoritmen kent een totaal andere aanpak. Eerst wordt er een flexibel raamwerk van mogelijke opvolgende of parallelle operaties op de beelden opgezet, het **neurale netwerk**. Vervolgens zoekt een specifiek hiervoor ontworpen algoritme binnen dit raamwerk de combinatie en volgorde van operaties die leidt tot de beste herkenning van de te detecteren objecten, **training**. Het trainingsalgoritme doet dit aan de hand van vooraf klaargezette verzameling van voorbeeldbeelden waarin de te detecteren objecten reeds zijn aangegeven, **gelabelde trainingsdata**. Na het training van het raamwerk op basis van de voorbeelddata, zal het resulterende algoritme ook in staat zijn om de te detecteren objecten te vinden in nieuwe beelden. Verdere details van dit type algoritmen zijn bijvoorbeeld terug te lezen in Géron (2019).

Bij de *machine-learning* aanpak is het dus niet meer nodig om de te detecteren objecten stapsgewijs te beschrijven in termen van beeldverwerkingsstappen. Voorbewerking, segmentatie, extractie van kenmerken en objectherkenning worden allemaal tegelijk en geïntegreerd uitgevoerd door het getrainde neurale netwerk. Het voordeel hiervan is dat deze methode erg krachtig en vooral erg robuust kan zijn. Door veel verschillende voorbeelden te bekijken tijdens de training ontstaan er vanzelf patronen die rekening houden met bijzonderheden en verschillende situaties (terwijl bij conventionele methoden iedere afwijking of bijzonderheid op voorhand expliciet moet worden voorzien en ondervangen door de ontwikkelaar). Het resulterende algoritme kan daardoor – net als mensen – in één oogopslag het te detecteren object herkennen. De uitdaging hierbij is dat er wel op voorhand genoeg, voldoende variërend trainingsmateriaal beschikbaar moet zijn. De ontwikkeling van een beeldherkenningsalgoritme op basis van *machine learning* kan dus pas beginnen zodra er een grote hoeveelheid beelden is verzameld waarin de te detecteren objecten (met de hand) al zijn aangegeven. Hoeveel trainingsdata er precies nodig is, hangt af van de complexiteit van de beelden en van de te detecteren objecten; de typische omvang varieert van duizenden tot miljoenen voorbeelden *pér* object dat gedetecteerd moet worden en/of *pér* situatie die beoordeeld moet worden. Het aantal benodigde voorbeelden kan daardoor gemakkelijk exploderen wanneer er veel variatie in de te analyseren beelden aanwezig is. Het gebrek aan voldoende voorbeelddata is het meest voorkomende knelpunt bij toepassing in vele sectoren. Het andere knelpunt, de grote rekenkracht die nodig is bij het trainen, wordt steeds minder belangrijk naarmate computerhardware steeds verder wordt ontwikkeld.

2.4 Usecases voor drinkwaterbedrijven

Uit de bovenstaande paragrafen blijkt vooral dat er reeds een rijkdom aan verschillende methoden en algoritmen beschikbaar is om objecten en beschadigingen te identificeren in videobeelden, zelfs wanneer het specifiek gaat om videobeelden van de binnenkant van leidingen (Tabel 2). Door de videobeelden te koppelen aan de positie van de camera in de leiding ontstaat een breed scala aan mogelijkheden om het digitale evenbeeld van het drinkwaterleidingnet verder aan te scherpen. Hier sommen we op welke zaken in een drinkwaterleiding waardevol zouden zijn om te identificeren, en waarom.

Merk op dat het hier steeds gaat om de locatie ten opzichte van de leiding van waaruit de beelden worden opgenomen. Voor de absolute locatie is aanvullende data nodig, bijvoorbeeld vanuit bekende referentiepunten en het bijhouden van de afgelegde weg.

Digitaal evenbeeld in termen van asseteigenschappen

- **Verbindingen:** de locatie van verbindingen (x, y, z) kan worden vastgesteld. Hiermee kan gerichter gegraven worden wanneer een verbinding met onvoldoende conditie (zie verderop) gerepareerd moet worden. De precieze locatie van verbindingen heeft ook waarde in conditiemodellen die toekomstige hoekverdraaiingen ten gevolge van bodembeweging proberen te extrapoleren. Tot op zekere hoogte zullen ook verschillende typen van verbindingen kunnen worden onderscheiden, zodat voor proactief onderhoud kan gaan worden bijgehouden of er cohorten van problematische verbindingen zijn.
- **Afsluiters:** de locatie van afsluiters (x, y, z) kan worden vastgesteld. Een van de belangrijkste faalmechanismen van afsluiters - onvindbaarheid, bijvoorbeeld door overstrating, zou met deze informatie verholpen kunnen worden. Tot op zekere hoogte zullen ook verschillende typen van afsluiters kunnen worden onderscheiden, zodat voor proactief onderhoud kan gaan worden bijgehouden of er cohorten van problematische verbindingen zijn.
- **Buizen:** de locatie van aftakkingen en aansluitleidingen (x, y, z) vanaf de geïnspecteerde buis kan worden vastgesteld. Dit helpt bij het opstellen van een nauwkeuriger beeld van de precieze ligging van het leidingen, waardoor buizen gerichter kunnen worden opgegraven en (graaf)schade door derden wordt gereduceerd. Ook kan het precieze materiaal van buizen worden vastgesteld en kan het LIS daar zo nodig op worden aangepast.
- **Reparatiestukken:** uit afstanden tussen verbindingen en de aanwezigheid van scheuren zonder lekkage die wijzen op klemmen (wellicht op basis van gecombineerde data) kunnen wellicht reparatiestukken worden geïdentificeerd. Deze breiden het inzicht in de storingsgeschiedenis en de conditie van het leidingnet uit.

Digitaal evenbeeld in termen van hydraulica

- **Afsluiters:** de precieze status van afsluiters kan worden vastgesteld. Dit biedt een extra controle en voeding van het afsluiter registratiesysteem, zodat afsluiters vaker goed staan.
- **Buizen:** de hierboven genoemde aanpassingen in de asseteigenschappen rond de precieze locatie, topologie en materialen, kunnen ook doorgevoerd worden in een nog nauwkeuriger hydraulisch model.

Digitaal evenbeeld in termen van conditie

- **Verbindingen:** uit de beelden van de spleet tussen verbinding en buis kan de aanwezigheid van een (ontwikkende) onacceptabele hoekverdraaiing of een risico op uitschuiven worden vastgesteld. Dit kan proactief onderhoud voeden.
- **Vervorming:** voor plastic buizen kunnen vervormingen worden vastgesteld die duiden op een probleem in de installatie, bijvoorbeeld vervormingen door puntbelastingen of ovaliteit vanwege slechte ondersteuning van een (te hoge) bovenbelasting. Dit kan proactief onderhoud voeden.
- **Degradatie:** In beelden van de buiswand zijn wellicht scheuren, beginnende scheuren of aantastingsplekken te onderscheiden. Op deze manier zouden latente lekken en calamiteiten in opkomst kunnen worden gevonden. Het is echter niet duidelijk of dit soort zaken ook daadwerkelijk zichtbaar zullen worden

aangetroffen in het leidingnet. Camerabeelden zullen waarschijnlijk vooral ondersteunend zijn aan andere sensoriek voor degradatie en lekkage.

Digitaal evenbeeld in termen van waterkwaliteit

- **Sediment:** op de bodem van buizen kan worden geïdentificeerd. Dit kan spuiplannen informeren en bruinwaterklachten voorkomen.
- **Biofilm:** de mate van aanwezigheid van biofilm kan worden vastgesteld. De precieze invloed van biofilm op de drinkwaterkwaliteit is nog steeds een punt van onderzoek (waar het breedschalig in kaart brengen van de aanwezigheid van biofilm aan bij kan dragen).
- **Leidingmateriaal:** het leidingmateriaal kan invloed hebben op de drinkwaterkwaliteit, dus het bepalen van het materiaal van buizen en aftakkingen (zie boven) kan helpen bij het opsporen van risicomaterialen.

3 Beeldherkenning toegepast op bestaande inspectiedata


In dit hoofdstuk demonstreren we de toepassingsmogelijkheden van beeldherkenning door enkele technieken die naar voren kwamen bij de studie beschreven in hoofdstuk 2 toe te passen op bestaande visuele inspectiedata. Eerst is de data verzameld. De detectiefuncties van het voorbeeldalgoritme en de onderliggende technieken zijn vervolgens gekozen en ontworpen op basis van de verschillende objecten die zichtbaar waren in de beschikbare beelden.

3.1 Case study data

Er kon data worden verzameld van drie verschillende waterbedrijven, vergaard met drie verschillende inspectieplatforms.

3.1.1 Evides


Evides leverde beelden van enkele (lege) PVC leidingen, opgenomen met één naar voren gerichte en één naar achter gerichte camera op een wagentje dat door de leidingen reed (IBAK PANORAMO). De camera's zijn uitgelijnd langs de lengteas van de leiding en bewegen met een constante snelheid door het systeem. De verzamelde data bestaat uit afzonderlijke, opvolgende foto's. In de beelden zijn een aantal verbindingen en aansluitingen te zien.



Figuur 3. Enkele videoframes uit de beelden van Evides. Links een beeld met een zichtbare verbinding; rechts een beeld met een zichtbare aansluiting.

3.1.2 Vitens


Vitens leverde beelden van een PVC leiding in bedrijf, opgenomen met een enkele camera die door het midden van de buis beweegt (Quasset). De camera is uitgelijnd langs de lengteas van de leiding en beweegt met een constante snelheid door het systeem. De data is een continu videobestand. In de beelden zijn een aantal verbindingen te zien. Ook zijn af en toe grote hoeveelheden belletjes en/of opgewerveld sediment zichtbaar en is de buiswand bedekt met onregelmatige patronen van biofilm en/of aanslag.



Figuur 4. Enkele videoframes uit de beelden van Vitens. Links een beeld met een zichtbare verbinding; rechts een beeld met opgewerveld materiaal.

3.1.3 WML

WML leverde beelde van enkele PVC en gietijzeren leidingen, opgenomen met een flexibele endoscoop. De data van één inspectie is een continu videobestand. In de beelden zijn opnieuw verbindingen te zien, maar ook aanslag op de buiswand en zelfs vervormingen. De endoscoop wordt op afstand, met de hand, door de leiding geduwd, zodat de camera met een steeds veranderende uitlijning en snelheid door de leiding beweegt. Monteurs gebruikten de endoscoop bovendien om ter plaatse te observeren en hielden de camera daarom af en toe stil om bijzonderheden beter te bekijken. In de beelden zijn een aantal verbindingen en vervormingen te zien. Ook zijn af en toe grote hoeveelheden sediment zichtbaar en is de buiswand bedekt met onregelmatige patronen van biofilm en/of aanslag.



Figuur 5. Enkele videoframes uit de beelden van WML. Linksboven een beeld met een zichtbare verbinding; rechtsboven een beeld met opgewerveld materiaal; linksonder een beeld met een zichtbare puntbelasting buiten de buis; rechtsonder een beeld met opnieuw een verbinding, nu zichtbaar onder een andere hoek.

3.2 Keuze voor een specifieke aanpak

Aangezien er slechts een beperkte set inspecties beschikbaar was (enkele honderden meters leidingnet), is gekozen om het demonstratiealgoritme te baseren op conventionele, stapsgewijze beeldverwerkings- en beeldherkenningstechnieken en niet op *machine learning*, waarvoor de grote databehoeftte ook hier weer het knelpunt is. Daarnaast is er gekozen om het algoritme ten eerste te richten op het identificeren van verbindingen, omdat dit de enige component was die voorkomt in alle films. Het uiteindelijke algoritme werd opgesteld in Matlab met behulp van kant-en-klare beeldherkenningsfunctionaliteit in Matlab's *image processing toolbox* en de *computer vision toolbox*.


3.3 Beeldherkenningsalgoritme voor verbindingen

De keuze voor een beeldherkenningsalgoritme op basis van conventionele technieken betekent dat het algoritme in een aantal expliciete stappen moet worden opgebouwd. Deze stappen zijn er op gericht om expliciet aan de computer 'uit te leggen' hoe de te detecteren objecten precies moeten worden geïdentificeerd. In de opvolgende paragrafen worden de stappen die nodig zijn om verbindingen in de beelden aan te wijzen. We sluiten daarbij zo goed mogelijk aan op de afzonderlijke stappen die werden toegelicht in Figuur 2.

3.3.1 Beelden inlezen en voorbereiden

Het algoritme wordt opgezet om steeds op afzonderlijke foto's te worden toegepast. Voor de data van Evides geldt dat deze al bestaat uit afzonderlijke foto's. De data van Vitens wordt in afzonderlijke foto's omgezet door de frames die horen bij iedere opvolgende 0,5 seconden te verzamelen.

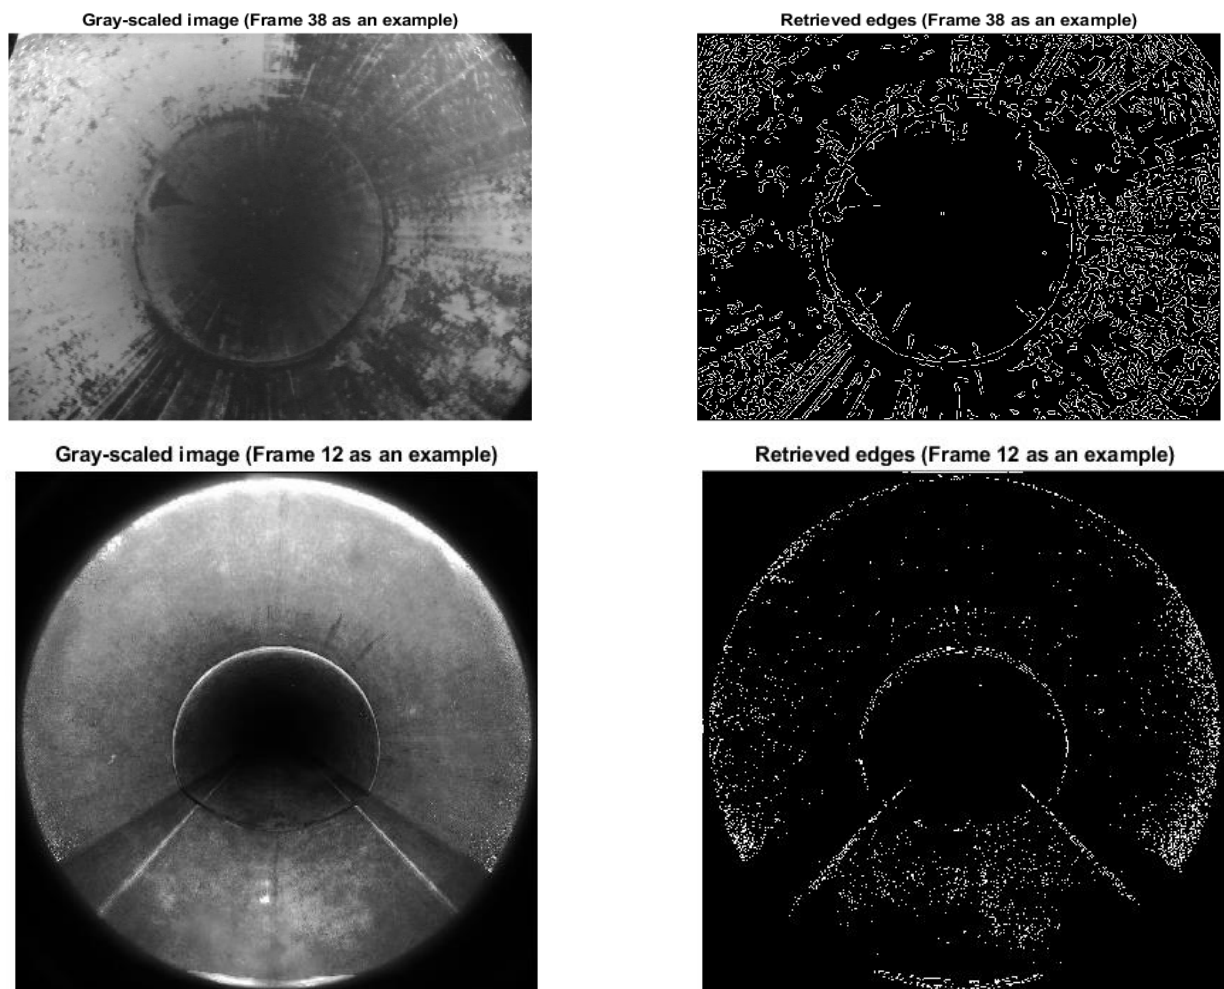
De foto's en videoframes worden ingelezen als een driedimensionale matrix met daarin de drie kleurkanalen (rood, groen, blauw, oftewel RGB). Dit is een gebruikelijke manier om een beeld met getallen weer te geven. Voor de centrale techniek in het algoritme wat we opzetten (de Houghtransformatie) is echter geen kleureninformatie nodig, enkel de intensiteit. Daarom worden de ingelezen frames vervolgens geconverteerd naar grijstinten: een tweedimensionale matrix met de grijswaarde per pixel. Dit is geïllustreerd voor de voorbeelddata in Figuur 6. Merk op dat analyse van kleurdata wel degelijk van waarde kan zijn voor andere technieken.



Figuur 6. Conversie naar grijstinten van de data van Viens (boven) en Evides (onder).

3.3.2 Segmentatie

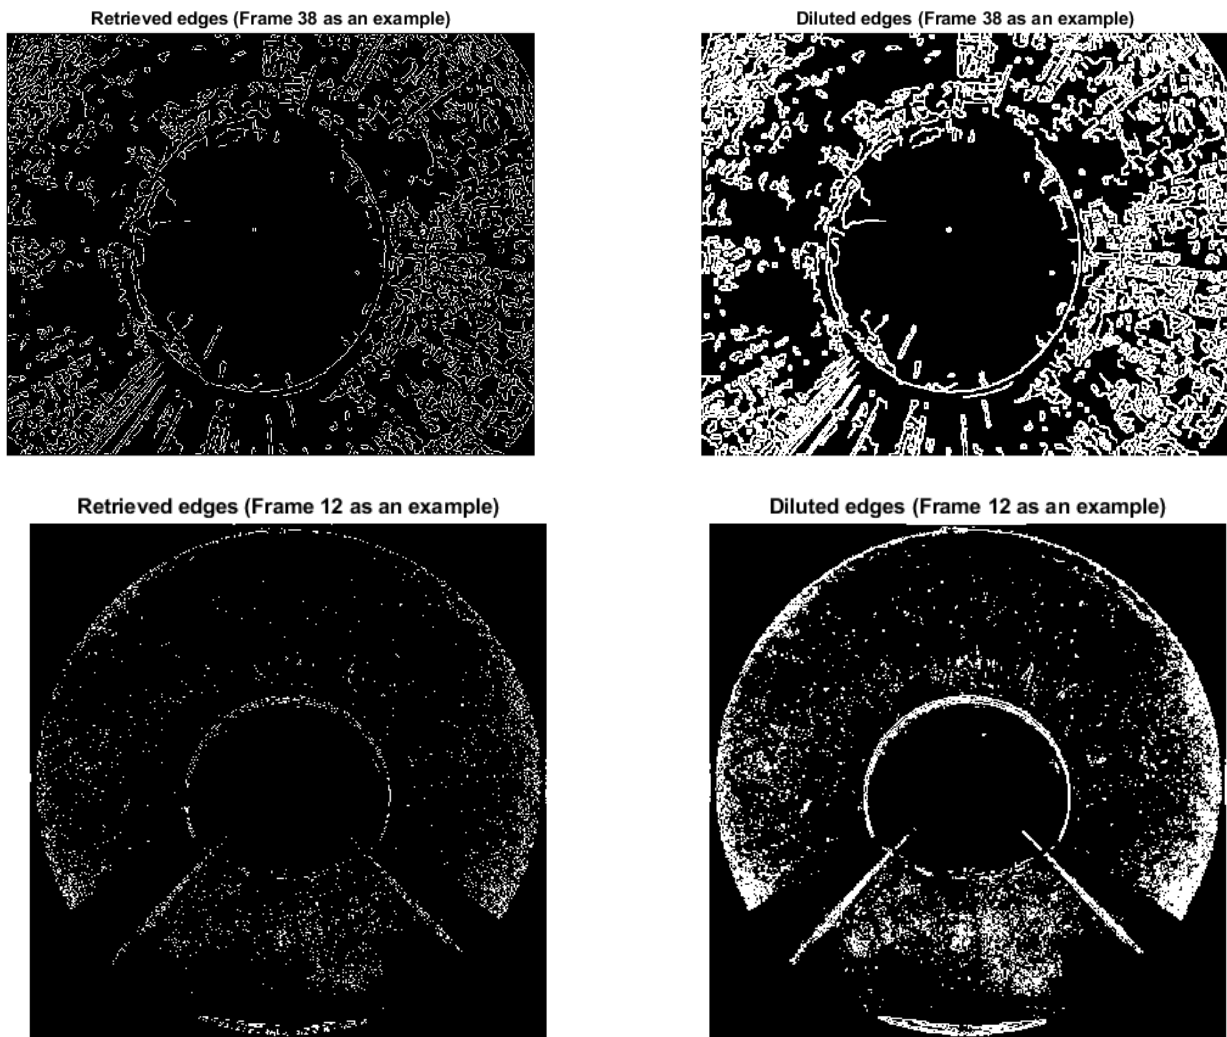
Daar waar mensen in één oogopslag de lijnen kunnen herkennen die de verbinding weergeven, 'ziet' het computer algoritme in eerste instantie niet eens lijnen. We benutten daarvoor een veelgebruikte segmentatiestap: randdetectie (edge detection). In deze stap worden via filters alle scherpe overgangen tussen lichte en donkere pixels opgespoord en gemarkeerd. In Figuur 7 is weergegeven welke overgangen in de voorbeelddata uiteindelijk worden gemarkeerd. Voor de computer betekent iedere witte pixel in de rechter plaatjes 'onderdeel van een lijn' en iedere zwarte pixel 'geen onderdeel van een lijn' (merk op dat wij als mens zelfs 'moeite' hebben om ons in de rechterplaatjes te concentreren op de afzonderlijke pixels in plaats van de lijnen die we direct weer herkennen). Merk op dat de rechterbeelden nu ook overstemd worden door de vele lijnen die zijn geïdentificeerd in de biofilm op de wand (met name voor de Vitens data).



Figuur 7. Segmentatie van lijnen in de data van Vitens (boven) en Evides (onder).

3.3.3 Dilatatie

In Figuur 7 is zichtbaar dat de verbindingen in de rechterplaatjes zijn ‘opgebouwd’ uit verschillende onderbroken lijnstukjes. Door de rechterplaatjes te dilateren (alle pixels die grenzen aan originele witte pixels ook wit maken; zie bijvoorbeeld van den Balen en van Boomgaard (1992) voor de wiskundige details), worden de lijnen dikker en versmelten ze met elkaar (). Door op deze manier de losse onderdelen van de ruis, maar vooral ook van de randen van de verbinding, te bundelen, wordt de volgende stap robuuster.




Figuur 8: Dilatatie van de uitkomst van de randdetectie voor de data van Vitens (boven) en Evides (onder).

3.3.4 Extractie van kenmerken met de Cirkel Houghtransformatie

Nu alle overgangen tussen lichte en donkere plekken in de beelden zijn gemarkeerd en versmolten, is de volgende stap in het algoritme om de computer hier 'lijnen' in te laten zien. Omdat we bovendien vooral geïnteresseerd zijn in de cirkel die de verbinding markeert, zoeken we expliciet naar cirkels. We gebruiken daarvoor de Cirkel Houghtransformatie voor (CHT), een gerenommeerde set rekenstappen om cirkels te vinden in plaatjes.


De kern van CHT is geïllustreerd in Figuur 9. In de linker figuur zijn 3 punten weergegeven op een cirkel met straal R . Wanneer men hier CHT op toepast, markeert men alle punten in het beeld die op een bepaalde afstand L van de drie punten liggen. Die verzameling gemarkeerde punten komt overeen met de onderbroken cirkels in het rechterfiguur. Als (en enkel als) L gelijk is aan R , zal het middelpunt van de originele cirkel (het oranje punt) drie keer gemarkeerd worden: één keer door iedere cirkel rond een van de punten. De CHT bestaat er uit om voor veel verschillende afstanden L hetzelfde plaatje te 'markeren' en steeds te zoeken naar punten die vaak gemarkeerd zijn. Een punt dat vaak gemarkeerd is voor een bepaalde afstand L is dan waarschijnlijk het middelpunt van een cirkel met straal L . De zwarte punten in het voorbeeld komen in ons geval overeen met de witte punten in de rechter plaatjes van Figuur 8.



Figuur 9: Illustratie van de kern van de Cirkel Houghtransformatie. De invoer bestaat uit de zwarte punten. Wanneer deze punten op een cirkel blijken te liggen, zal de uitvoer bestaan uit het middelpunt van die cirkel en de straal die daar bij hoort (het oranje punt en de straal van de onderbroken 'zoekcirkels').

De kracht van deze aanpak is dat een onvolledige cirkel ook kan worden gedetecteerd: in Figuur 9 wordt de cirkel op basis van slechts drie punten al gevonden, omdat het oranje punt duidelijk het vaakst 'gemarkeerd' wordt. Werkelijke toepassing is daarmee wel erg gevoelig voor de definitie van een grenswaarde die uitwijst wanneer een punt vaak genoeg 'gemarkeerd' is om ook te worden aangemerkt als middelpunt van een cirkel. Er kan een bereik van zoekafstanden L die moeten worden geprobeerd worden gekozen om de iteraties en rekentijd van de transformatie te beperken.

In onze toepassing bleek een relatieve grenswaarde van 0,98 (overeenkomstig met de 2% vaakst gemarkeerde middelpunten) werkbaar. Dan nog werden er veel cirkels gevonden in de voorbeelddata, zoals te zien is in de linker plaatjes in Figuur 10. We brengen daarom nog een expliciete stap in het herkenningsproces aan: de cirkel met het middelpunt dat het dichtst bij het middelpunt van de foto ligt, moet de verbinding zijn. We kunnen deze stap alleen maar toepassen omdat we weten dat de camera is uitgelijnd langs de lengteas van de buis. Dit benadrukt prachtig hoe een (en in ieder geval dit) beeldverwerkingsalgoritme dus in feite al begint met het kiezen van de meetopstelling voor opname van de beelden. Voor de beelden van WML zou dit niet gewerkt hebben omdat deze niet zijn uitgelijnd zoals de beelden van Vitens en Evides.




Figuur 10: Ruwe uitkomst van de Cirkel Houghtransformatie met een gevoeligheid van 0,98 (links) en de cirkel daarbinnen die het dichtst bij het middelpunt van de foto ligt (rechts), voor de data van Vitens (boven) en Evides (onder).

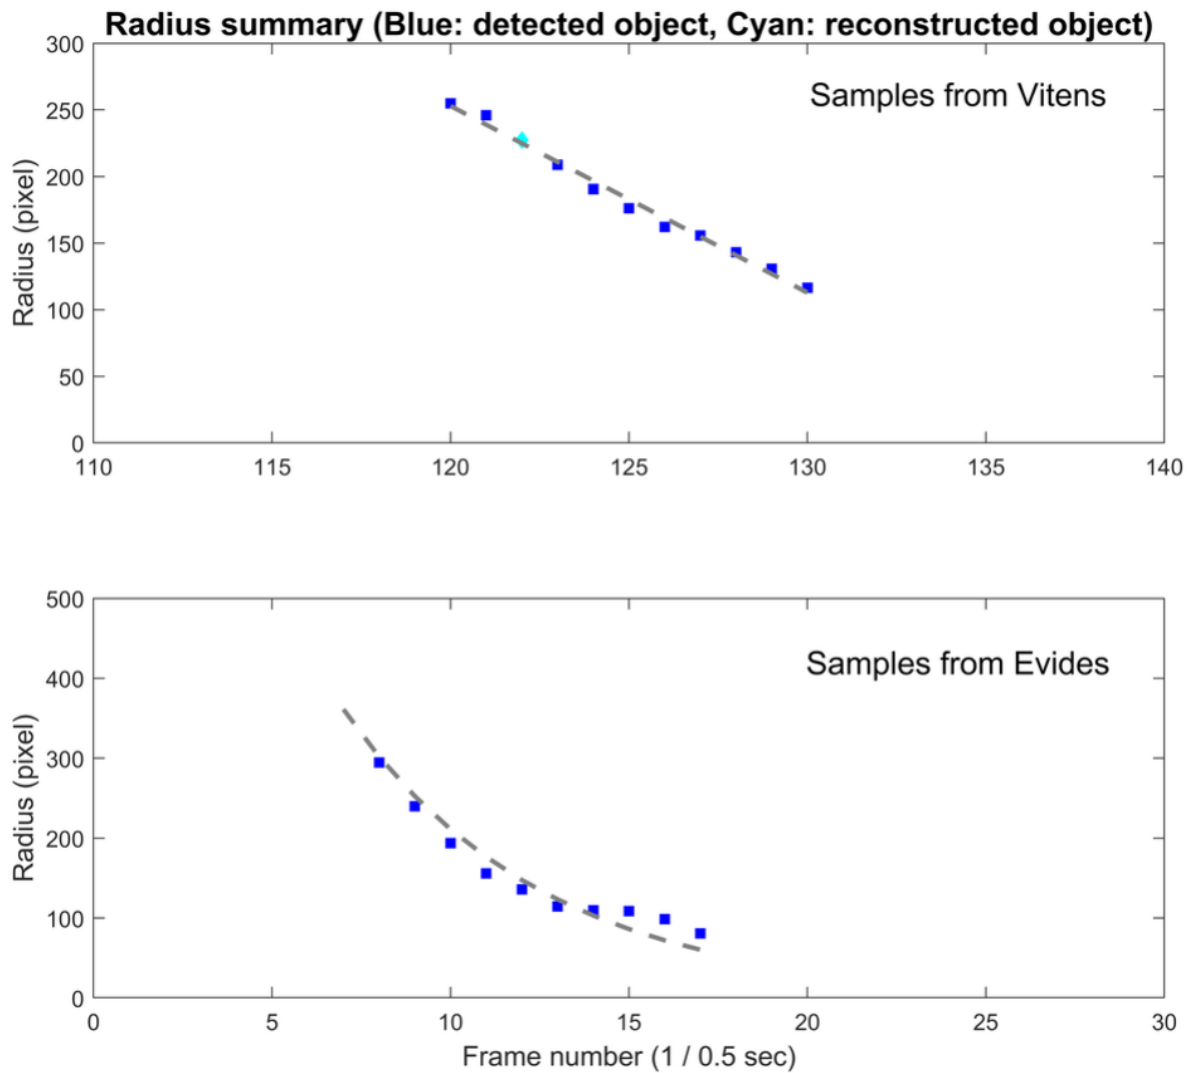
In Figuur 10 zien we inderdaad dat het algoritme cirkels heeft weten te tekenen die overeenkomen met de verbinding. Het feit dat een verbinding meerdere frames zichtbaar is in de video (Figuur 11) maakt de methode des te robuuster. In de gecombineerde data van alle frames in een video maakt het in principe niet uit als de verbinding een enkele keer niet gedetecteerd wordt. In Figuur 12 is de straal van de verbinding in opeenvolgende frames geplot voor de voorbeelddata. De straal neemt af omdat de verbinding in het plaatje steeds kleiner wordt (de camera beweegt 'achteruit').

De reden dat de straal van de verbinding zoals zichtbaar in de Evides data niet gelijkmatig verandert net als in de data van Vitens, is dat de gebruikte camera een bijzondere lens gebruikt om een grotere kijkhoek te realiseren. Meer algemeen laat dit opnieuw zien dat de benodigde stappen bij beeldverwerking ook samenhangen met de precieze technische invulling van het verzamelen van de beelden.

Dit algoritme maakt expliciet gebruik van de aanname dat de camera langs de lengteas van de buis is uitgelijnd. Het is daarom minder geschikt voor het verwerken van de endoscoopbeelden van WML. In Figuur 13 wordt getoond dat het algoritme ook bruikbaar is voor de beelden van WML wanneer het gaat om verbindingen die onder een vergelijkbare hoek zijn gefotografeerd.



Figuur 11. Enkele opeenvolgende frames in de data van Vitens. De verbinding is meerdere frames lang zichtbaar.




Figuur 12. De gedetecteerde straal van de verbinding in opeenvolgende frames voor de data van Vitens (boven) en Evides (onder). Lichtblauwe punten werden door het algoritme gemist, maar het algoritme is trefzeker genoeg om de verbinding in het merendeel van de opeenvolgende frames te detecteren (blauwe punten).



Figuur 13. Uitkomst van het algoritme wanneer toegepast op een verbinding in de beelden van WML, gefotografeerd onder een vergelijkbare hoek, bij benadering vanaf de lengteas van de buis.

3.4 Het herkennen van aansluitleidingen

In de beelden van Evides zijn ook aftakkingen naar aansluitleidingen te zien. Voortbouwend op de stappen die zijn beschreven in 3.3.1 tot en met 3.3.3 kon een algoritme gemaakt worden om deze te herkennen. Door te zoeken naar het grootste witte object in de bovenkant van het beeld (zodat er geen problemen ontstaan met het deel van de robot dat systematisch in beeld is), wordt de aansluitleiding gevonden. Merk op dat deze techniek alleen kon werken omdat er relatief weinig ruis door biofilm en andere verstoringen aanwezig is in de beelden van Evides.



Figuur 14: Herkenning van aftakkingen naar aansluitleidingen in de data van Evides.

4 Naar de toepassing van beeldherkenning voor automatische interpretatie van inspecties

4.1 Discussie

Het overzicht uit hoofdstuk 2 en de illustratie uit hoofdstuk 3 laten zien dat er reeds een grote hoeveelheid beeldherkenningsmethoden beschikbaar is waarmee veel verschillende aspecten van videobeelden van leidingen in kaart zouden kunnen worden gebracht. Het is de moeite waard om te benadrukken dat men met conventionele technieken al ver blijkt te kunnen komen met de data die op dit moment en in de nabije toekomst beschikbaar is, terwijl de doorbraak van – het weliswaar veel krachtigere en flexibelere – *machine learning* nog op zich zal moeten laten wachten tot er een substantiële dataset is opgebouwd. Ongeacht de keuze voor een bepaalde technische oplossing op de korte termijn, zijn er een aantal zaken waarmee rekening gehouden kan worden om een automatische interpretatie van video-inspecties van leidingen te bespoedigen.

Om conventionele beeldherkenningstechnieken goed toe te kunnen passen is een goed begrip nodig van het te detecteren object en van de manier waarop dit te herkennen is in een videobeeld. Ook in dit geval zijn enige voorbeelden van beelden van het te detecteren object nodig, net als in het geval van moderne *machine-learning* technieken, die een veelvoud van dergelijke voorbeelden nodig hebben. Data moet dus verzameld worden vóór dat de verwerkingsalgoritmen kunnen worden ontwikkeld.

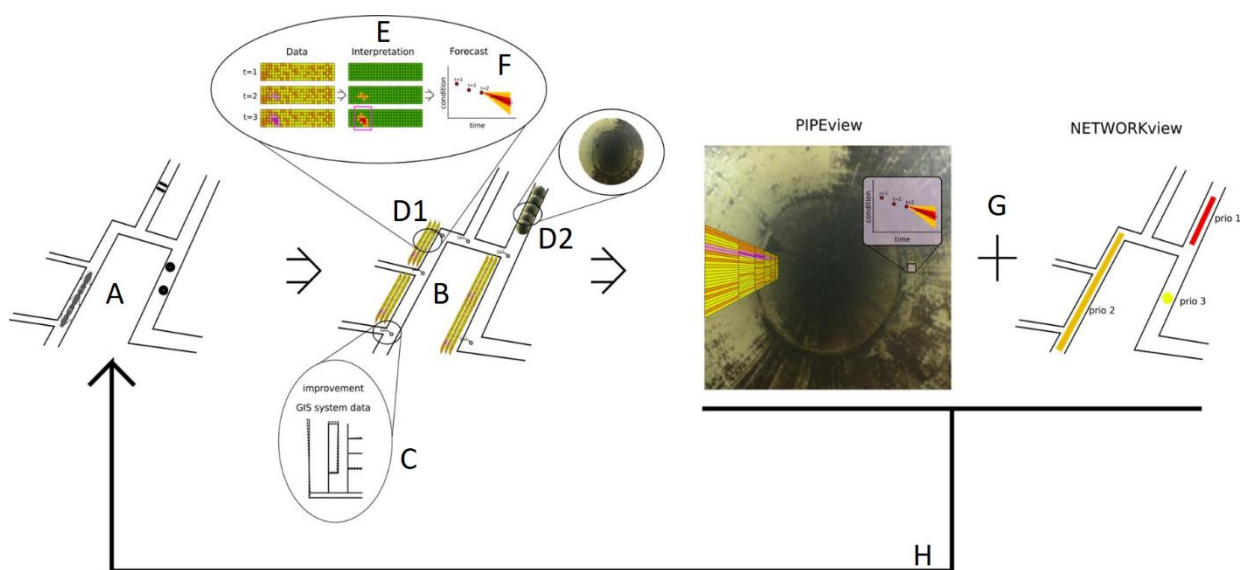
In beide gevallen zal de kwaliteit en homogeniteit van de beelden de toepassing van beeldherkenning vergemakkelijken. In het geval van conventionele technieken geldt dat iedere bijzonderheid apart moet worden geadresseerd met extra oplossingen in het algoritme, zodat homogener beelden zullen leiden tot eenvoudigere, robuustere algoritmen. In het geval van moderne *machine-learning* technieken geldt dat er extra trainingsdata moet worden verzameld om iedere bijzonderheid in te regelen, dus als beelden homogener worden verzameld, hoeven er minder van verzameld te worden vóór deze technieken binnen bereik komen. Omdat het aantal benodigde voorbeelden makkelijk explodeert, is een gedegen gestandaardiseerde methode voor het verzamelen van beelden – voor toekomstige toepassing van *machine-learning* technieken – geen kwestie van comfort, maar een essentiële voorwaarde. Het standaardiseren van de systemen voor het verzamelen van beelden zal ook essentieel zijn als men op de beelden kwantitatieve metingen wil baseren (bijvoorbeeld identificatie van biofilm op basis van kleur of het meter van de diameter op basis van vorm). Kortom: effectieve beeldverwerking kan niet achteraf op om het even welke beelden worden toegepast. Om goede resultaten te behalen moet het ontwerp van de beeldverzameling op de automatische verwerking voorsorteren.

Als drinkwaterbedrijven een homogene data-acquisitie onderling weten af te stemmen (zoals bijvoorbeeld in het initiatief tot een praktijkcode voor een Informatiemodel van leidinginspecties, dat op het moment van schrijven wordt opgestart binnen het Platform Bedrijfsvoering), zullen zij bovendien hun krachten kunnen bundelen door conventionele algoritmen te delen en samen trainingssets op te bouwen. Binnen de voorbeelden die zijn gebruikt in het huidige onderzoek hebben de beelden van de IBAK en de Quasset wat dat betreft duidelijk de voorkeur ten opzichte van de beelden van de endoscopen.

Hoewel dit onderzoek zich richtte op beeldverwerking als voorbeeld, staan videobeelden van een inspectie nooit op zichzelf. Data uit andere informatiebronnen, al dan niet verkregen bij dezelfde inspectie, kunnen met videobeelden gecombineerd worden voor een beter beeld van de algehele toestand. Een microfoon is bijvoorbeeld waarschijnlijk beter geschikt om verborgen lekken ter plaatse te detecteren, maar de combinatie met videobeelden zou daar vervolgens informatie over oorzaak en over de snelheid waarmee de toestand verslechtert kunnen toevoegen.

Daarnaast is er ook informatie die onmisbaar is voor een goede verwerking van de beelden. Om beelden en de bijzonderheden die daarin zijn gedetecteerd goed te kunnen duiden en in te kunnen bedden in het proces van het drinkwaterbedrijf, zal bijvoorbeeld altijd nauwkeurige informatie over de positie van de camera tijdens het moment van opname beschikbaar moeten zijn. Een camera kan (met beeldherkenningstechnieken en diameter als invoer, zie ook Tabel 2) wel de eigen relatieve positie in de leiding bijhouden, maar uiteindelijk zal de meting als geheel altijd een of meerdere referentiepunten met bekende ruimtelijke coördinaten nodig hebben.

Het is dus belangrijk om na te denken over hoe verschillende databronnen en uitkomsten van verwerkingen ruimtelijk gekoppeld kunnen worden aan elkaar en aan het (G)LIS van de drinkwaterbedrijven. Figuur 15 schetst een beeld van hoe de beelden en hun verwerking via een koppeling met geo-informatie zouden kunnen worden ingebed in het proces van het drinkwaterbedrijf.



Figuur 15. Schematische weergave van een mogelijke architectuur voor de datastromen rond automatische leidinginspecties. Een inspectieplatform verzamelt data in het leidingnet (A). Op basis van de positie van het inspectieplatform wordt de verzamelde data in een GIS-laag gekoppeld aan de verschillende locaties in het leidingnet (B). Merk op dat het mogelijk nodig is om de bestaande GIS-data van het leidingnet aan te passen op basis van inzichten uit de verzamelde data (C). Gekoppelde data kan verschillende bronnen hebben, zoals een ultrasoon-scan van de wand (D1) of videobeelden (D2). Algoritmen voor automatische interpretatie identificeren bijzonderheden in de data (E) en destilleren hieruit invoer voor verdere beslissingsondersteuning, zoals bijvoorbeeld een conditiemodel (F). Wanneer een medewerker van het drinkwaterbedrijf op zoek is naar bijzonderheden over een bepaalde leiding, kan alle beschikbare data en de verdere verwerking daarvan opnieuw worden teruggeroepen (G). Deze informatie kan vervolgens beslissingen over ingrepen in het leidingnet ondersteunen, zoals onderhoud, meegaan met derden of spuien (H). Als er behoefte is aan meer informatie, kunnen er desgewenst nieuwe inspecties worden opgezet (H).

4.2 Conclusies

Beeldherkenning is een breed ontwikkeld veld dat de drinkwatersector veel mogelijkheden biedt voor de automatische interpretatie van huidige en toekomstige inspectiebeelden (hoofdstuk 2).

Conventionele beeldherkenningstechnieken bieden een goed startpunt voor het verkennen en verwerken van de (beperkte) verzameling beelden die op dit moment in de sector wordt opgebouwd. Om dergelijke algoritmes efficiënt en robuust toe te kunnen passen is het wel nodig om data zoveel mogelijk op een eenduidige wijze te verzamelen (hoofdstuk 2 en 3).

Toepassing van moderne *machine-learning*technieken is op dit moment niet aan de orde vanwege het gebruikelijke knelpunt van de grote hoeveelheid reeds geïnterpreteerde data die op voorhand nodig is bij de training van de algoritmen. Om zo snel mogelijk gebruik te kunnen gaan maken van deze krachtige techniek is het absoluut noodzakelijk om data zoveel mogelijk op een eenduidige wijze te verzamelen en bovendien ook om deze data zo eenduidig mogelijk te interpreteren; conventionele beeldherkenningstechnieken kunnen bij het construeren van de trainingsdata al veel werk uit handen nemen door te helpen bij het labelen van de data (hoofdstuk 2).

4.3 Roadmap/aanbevelingen voor drinkwaterbedrijven om te komen tot automatische interpretatie van visuele inspecties

Om goed voor te sorteren op toekomstige automatische verwerking van data moeten eerst de volgende twee onderwerpen worden geadresseerd:

- **Uniforme inspectie**
 - Stel vast hoe videobeelden zoveel mogelijk op eenduidige wijze kunnen worden verzameld, zodat toekomstige analyse en duiding breed inzetbaar en reproduceerbaar kunnen zijn. Probeer dit ook af te stemmen met de collega-drinkwaterbedrijven voor nog meer effectiviteit (Bijvoorbeeld binnen het lopende initiatief tot een praktijkcode voor een informatiemodel van leidinginspecties in het Platform bedrijfsvoering).
 - Het is belangrijk om te benadrukken dat dit geen vrijblijvende stap is als men in de toekomst beelden automatisch wil verwerken, maar een noodzakelijke voorwaarde die automatisering kan maken of breken.
- **Uniform datamodel**
 - Stel vast hoe verzamelde beelden zo veel mogelijk op eenduidige wijze geografisch kunnen worden gekoppeld aan het (G)LIS, zodat deze kunnen worden teruggevonden en zodat (automatische) interpretatie makkelijk op het leidingnet kan worden betrokken.
 - Doe hetzelfde voor andere verzamelde data, zodat verschillende databronnen elkaar kunnen ondersteunen in de automatische interpretatie.
 - Doe het zelfde voor de uitkomsten van algoritmen voor automatische interpretatie van de data, zodat ook deze uitkomsten gemakkelijk kunnen worden teruggevonden en kunnen worden doorgevoerd in volgende verwerkingsstappen.
 - Stel vast hoe nieuwe inzichten die conflicteren met het actuele (G)LIS zullen worden verwerkt.
 - Probeer dit alles ook af te stemmen met de collega-drinkwaterbedrijven voor nog meer effectiviteit (Bijvoorbeeld binnen het lopende initiatief tot een praktijkcode voor een informatiemodel van leidinginspecties in het Platform bedrijfsvoering).

Vervolgens kunnen zowel conventionele als moderne beeldherkenningstechnieken alleen maar worden ontwikkeld aan de hand van bestaande voorbeelden. De eerste set data die wordt verzameld kan dienen als een fundament voor de ontwikkeling van specifieke methoden voor automatische interpretatie van beelden die in de toekomst worden verzameld:

- **Eerste data**
 - Verzamel de eerste data met de vorige twee onderwerpen in het achterhoofd.
 - Gebruik conventionele beeldherkenning ter ondersteuning van het (handmatig) verkennen en interpreteren van deze eerste data sets.
 - Uniforme inspectie binnen een drinkwaterbedrijf stelt het bedrijf in staat om ook *unsupervised machine-learning* technieken (zoals het laatste voorbeeld in Tabel 2) te gebruiken bij het zoeken naar bijzonderheden. Uniforme inspectie en een uniform datamodel stellen de drinkwaterbedrijven in staat om hier de krachten te bundelen.
 - Stel een overzicht op van alle bijzonderheden die kunnen worden aangetroffen in de videobeelden en de relevantie van ieder van deze bijzonderheden voor het proces van de drinkwaterbedrijven. Uniforme inspectie en een uniform datamodel stellen de drinkwaterbedrijven in staat om hier de krachten te bundelen.
- **Automatische interpretatie van inspectiedata**
 - Blijf de conventionele beeldherkenning die is ontwikkeld voor de eerste data gebruiken in die gevallen waar deze robuust genoeg is gebleken om op zichzelf te staan.

- Op basis van de eerste data en het overzicht dat daarvan is opgesteld kan een *machine-learning* algoritme voor robuustere beeldherkenning worden getraind. Uniforme inspectie en een uniform datamodel stellen de drinkwaterbedrijven in staat om hier de krachten te bundelen.

4.4 Aanbeveling voor gerelateerd onderzoek

Dit onderzoek richtte zich op de automatische interpretatie van data: het vertalen van ruwe data naar leidingeigenschappen (videobeelden, radar- en geluidssignalen, gps-coördinaten en andere meetgegevens vertalen naar afsluiterstanden, wanddiktes, materialen, diameters, locaties van buizen, verbindingen of appendages en dergelijken). Er is een steeds grotere behoefte om beslissingen over het drinkwaterproces op te ondersteunen met een modelmatige vertaling van dergelijke leidingeigenschappen naar abstractere leidinginformatie, zoals conditie, risico op OLM, risico op waterkwaliteitsklachten, de toekomstige ontwikkeling van situaties, enzovoorts. Het zou gesteld kunnen worden dat de rekenmodellen die hiertoe zijn ontwikkeld (denk aan conditie- en verouderingsmodellen, maar bijvoorbeeld ook aan hydraulische netwerkmodellen) het afgelopen decennium hebben voorgelopen op de beschikbaarheid van de hiervoor benodigde invoer-, kalibratie- en validatiedata. Nu het steeds beter bekend wordt welke leidingeigenschappen in de toekomst op grote schaal zullen kunnen worden gemeten, is het aan te bevelen om ook te onderzoeken welke van deze eigenschappen een bijdrage kunnen leveren aan beslissingen over het drinkwaterproces en welke kennisregels of modellen er nodig zijn om dat mogelijk te maken. Op die manier wordt een volgende cruciale stap gezet in de weg van data naar beslissing. De verdere ontwikkeling van beeldherkenning en andere automatische data-interpretatie kan daarmee ook beter geprioriteerd worden om zich te richten op die leidingeigenschappen die een bijdrage kunnen leveren.

5 Literatuur

V. Bondada, D. K. Pratihari, en C. S. Kumar, "Detection and quantitative assessment of corrosion on pipelines through image analysis," *Procedia Comput. Sci.*, vol. 133, pp. 804–811, 2018, doi: 10.1016/j.procs.2018.07.115.

R. van den Boomgaard en R. van Balen, "Methods for fast morphological image transforms using bitmapped binary images," *CVGIP Graph. Model. Image Process.*, vol. 54, no. 3, pp. 252–258, May 1992, doi: 10.1016/1049-9652(92)90055-3.

A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2nd ed. O'Reilly Media, Inc., 2019.

J. B. Haurum en T. B. Moeslund, "A Survey on Image-Based Automation of CCTV and SSET Sewer Inspections," *Autom. Constr.*, vol. 111, no. November 2019, p. 103061, Mar. 2020, doi: 10.1016/j.autcon.2019.103061.

Halfaway, M. R., Hengmeechai, J., Optical flow techniques for estimation of camera motion parameters in sewer closed circuit television inspection videos. *Autom. Constr.*, vol. 38, pp. 39-45, 2014

N.-D. Hoang, "Detection of Surface Crack in Building Structures Using Image Processing Technique with an Improved Otsu Method for Image Thresholding," *Adv. Civ. Eng.*, vol. 2018, pp. 1–10, 2018, doi: 10.1155/2018/3924120.

S. Kirstein, K. Müller, M. Walecki-Mingers, en T. M. Deserno, "Robust adaptive flow line detection in sewer pipes," *Autom. Constr.*, vol. 21, no. 1, pp. 24–31, 2012, doi: 10.1016/j.autcon.2011.05.009.

J. Kunzel, T. Werner, P. Eisert, en J. Waschnewski, "Automatic Analysis of Sewer Pipes Based on Unrolled Monocular Fisheye Images," in *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Mar. 2018, vol. 2018-Janua, no. March, pp. 2019–2027, doi: 10.1109/WACV.2018.00223.

N. Kussul, M. Lavreniuk, S. Skakun, en A. Shelestov, "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data," *IEEE Geosci. Remote Sens. Lett.*, vol. 14, no. 5, pp. 778–782, May 2017, doi: 10.1109/LGRS.2017.2681128.

Z. Liu en Y. Kleiner, "State of the art review of inspection technologies for condition assessment of water pipes," *Meas. J. Int. Meas. Confed.*, vol. 46, no. 1, pp. 1–15, 2013, doi: 10.1016/j.measurement.2012.05.032.

Mashford, J., Marlow, D., Burn, S., "An Approach to Pipe Image Interpretation Based Condition Assessment for Automatic Pipe Inspection" *Adv. Civ. Eng.*, vol. 2009, article ID 317097, doi: 10.1155/2009/317097.

J. R. Parker, *Algorithms for Image Processing and Computer Vision*, 2nd ed. 2010.

T. C. Su, M. Der Yang, T. C. Wu, en J. Y. Lin, "Morphological segmentation based on edge detection for sewer pipe defects on CCTV images," *Expert Syst. Appl.*, vol. 38, no. 10, pp. 13094–13114, 2011, doi: 10.1016/j.eswa.2011.04.116.

X. Yin, Y. Chen, A. Bouferguene, H. Zaman, M. Al-Hussein, en L. Kurach, "A deep learning-based framework for an automated defect detection system for sewer pipes," *Autom. Constr.*, vol. 109, no. August 2019, p. 102967, 2020, doi: 10.1016/j.autcon.2019.102967.

Y. Zhang, J. Wang, en X. Yang, "Real-time vehicle detection and tracking in video based on faster R-CNN," J. Phys. Conf. Ser., vol. 887, no. 1, p. 012068, Aug. 2017, doi: 10.1088/1742-6596/887/1/012068.